

Faculty of Health Sciences

# Basal Statistik

## Logistisk regression mm. i R

Lene Theil Skovgaard

28. oktober 2019



# Logistisk regression mm.

- ▶ Modeller for binært outcome
  - ▶ Repetition vedrørende tabeller
  - ▶ **Logistisk regression**
  - ▶ Modelkontrol
  - ▶ Alternative links
- ▶ Ordinal regression  
*og hvis vi når det...:*
- ▶ Poisson regression

Hjemmesider:

[http://publicifsv.sund.ku.dk/~lts/basal19\\_2](http://publicifsv.sund.ku.dk/~lts/basal19_2)

E-mail: ltsk@sund.ku.dk



# Typer af outcome

- ▶ Kvantitative data  
Den generelle lineære model
- ▶ Binære data 0/1-data  
Logistisk regression
- ▶ Ordinale data  
Proportional odds regression, Ordinal regression
- ▶ Tælletal  
Poisson regression
- ▶ Censurerede data (overlevelsedata)  
Cox regression



# Eksempel fra tidligere: Farveblindhed og køn

		Farveblindhed?		
		nej	ja	Total
Piger	119		1	120
Drenge	144		6	150
Total	263		7	270

Outcome Y: Farveblindhed  
dikotom, 0/1, nej/ja

Kovariat: Køn:  
dikotom, 0/1, pige/dreng

Er farveblindhed lige hyppigt blandt drenge og piger?, dvs.  
Er farveblindhed **uafhængig** af køn?

- $p_d$  Sandsynlighed for farveblindhed blandt drenge
- $p_p$  Sandsynlighed for farveblindhed blandt piger

Hypotese:  $p_d = p_p$



# Mål for kønseffekt på farveblindhed

f.eks. drenge vs. piger:

Differens:  $p_d - p_p$

Risk Ratio:  $RR = \frac{p_d}{p_p}$

Odds Ratio:  $OR = \frac{p_d/(1-p_d)}{p_p/(1-p_p)}$



# Test for uafhængighed

Hypotese:  $p_d = p_p$  (RR=OR=1)

testes med

- ▶ Chi-i-anden test ( $\chi^2$ -test),  
med mindre tabellerne er ret *tynde*, dvs.  
hvis der er forventede værdier under 5...

Så bruges i stedet

- ▶ Fishers eksakte test  
(kan altid anvendes)
- som altså er test for uafhængighed,  
mellem kovariat (køn) og outcome (farveblindhed)



# Opsætning af tabellen

Se samlet kode s. 95

```
fb = matrix(c(1,6,119,144), nrow=2)
rownames(fb) = c("Piger", "Drenge")
colnames(fb) = c("ja", "nej")
```

```
> addmargins(fb)
      ja nej Sum
Piger   1 119 120
Drenge  6 144 150
Sum     7 263 270
```

```
> prop.table(fb,1)*100
      ja      nej
Piger  0.8333333 99.16667
Drenge 4.0000000 96.00000
```

```
> chisq.test(fb)$expected
      ja      nej
Piger  3.111111 116.8889
Drenge 3.888889 146.1111
Warning message:
In chisq.test(fb) : Chi-squared approximation may be incorrect
```



# Test af hypotesen om uafhængighed

```
> chisq.test(fb)
Pearson's Chi-squared test with Yates' continuity correction

data: fb
X-squared = 1.5418, df = 1, p-value = 0.2144

Warning message:
In chisq.test(fb) : Chi-squared approximation may be incorrect

> fisher.test(fb)
Fisher's Exact Test for Count Data

data: fb
p-value = 0.1364
alternative hypothesis: true odds ratio is not equal to 1
```

Vi kan altså *ikke afvise*, at forekomsten af farveblindhed er ens for drenge og piger ( $P=0.14$ )



# Differens mellem sandsynlighederne

Vi må selv udregne differensen:

$$\hat{p}_p - \hat{p}_d = -0.0317, CI = (-0.0745, 0.0112):$$

```
> prop.test(fb)

2-sample test for equality of proportions with continuity correction

data: fb
X-squared = 1.5418, df = 1, p-value = 0.2144
alternative hypothesis: two.sided
95 percent confidence interval:
-0.07449312 0.01115979
sample estimates:
prop 1     prop 2
0.008333333 0.040000000

Warning message:
In prop.test(fb) : Chi-squared approximation may be incorrect
```

Der er altså ca. 3% flere drenge end piger, der er farveblinde.



# Relativ risiko og odds ratio

Risk ratio = relativ risiko (RR=4.80),

```
install.packages("epitools")
library(epitools)

> epitab(fb,method="riskratio",rev="columns")$tab
      nej      p0 ja      p1 riskratio      lower      upper      p.value
Piger  119 0.9916667 1 0.008333333    1.0       NA       NA       NA
Drenge 144 0.9600000 6 0.040000000    4.8 0.5858252 39.32914 0.1363846
```

Odds ratio (OR=4.96)

```
> epitab(fb,method="oddsratio",rev="rows")$tab
      ja      p0 nej      p1 oddsratio      lower      upper      p.value
Drenge  6 0.8571429 144 0.5475285  1.000000       NA       NA       NA
Piger   1 0.1428571 119 0.4524715  4.958333 0.5887152 41.76055 0.1363846
```



## Nyt eksempel: Postoperative sårinfektioner

194 patienter opereret på Frederiksberg Hospital.

For hver patient  $i$  registreres:

- ▶  $x_{i1}$ =optid, operationens varighed i minutter
- ▶  $x_{i2}$ =alder, i år
- ▶  $y_i$ =infektion=  
$$\begin{cases} 1 & \text{postoperativ sårinfektion (n=23)} \\ 0 & \text{ingen postoperativ sårinfektion (n=171)} \end{cases}$$

```
> summary(inf[,2:4])
   infektion          optid           alder
  Min.   :0.0000  Min.   : 5.00  Min.   : 7.00
  1st Qu.:0.0000  1st Qu.:50.00  1st Qu.:30.00
  Median :0.0000  Median :75.00  Median :64.50
  Mean   :0.1186  Mean   :93.94  Mean   :55.97
  3rd Qu.:0.0000  3rd Qu.:120.00 3rd Qu.:77.75
  Max.   :1.0000  Max.   :390.00  Max.   :90.00
```



# Problemstilling

Hvordan afhænger sandsynligheden for at få postoperativ sårinfektion af alder og operationstid?

**Outcome:** Sårinfektion ja/nej,  
et binært/dikotomt outcome (0-1 variabel)

**Kovariater** vælges her som:

- ▶ Patientens alder, som lineær effekt  
(evt. som alder pr. 10-år ved at skalere til  
 $alder10=alder/10$ )
- ▶ Indikator for operationsvarighed over 2 timer:  
$$\text{over2timer} = \begin{cases} 1 & : \text{ hvis optid} > 120 \\ 0 & : \text{ ellers} \end{cases}$$


Model for  $p_i$ 'erne? Først plejer vi at tegne...



# Figurer

Plot af infektion vs. alder, med loess-smoother (kode s. 96)

Blå: over 2 timer, Rød: under 2 timer



Figurerne er rigtigt grimme,  
når outcome kun antager 2 forskellige værdier



## Model for $p_i$ 'erne

Adskillige ting ***dur ikke*** i denne situation med binært outcome og kvantitativ kovariat (her alder):

- ▶ Figurer er ikke særlig kønne, fordi outcome er binært
- ▶ Tabeller dur ikke, fordi alder har for mange værdier
  - her 68 forskellige aldre
- ▶ Den sædvanlige linearitetsantagelse (for effekten af kovariaten alder) er ikke god for sandsynligheder, fordi en linie ikke er begrænset, hverken nedadtil eller opadtil, så vi kommer let udenfor området mellem 0 og 1
  - *og det er mildest talt ikke så rart, når man har med sandsynligheder at gøre*



## Model for $p_i$ 'erne, fortsat

Vi har brug for at **transformere**  $p_i$ 'erne, før vi kan antage linearitet

- ▶ Derfor bruger man en funktion  $g(p_i)$ , kaldet **link-funktionen**, og antager linearitet på denne skala.

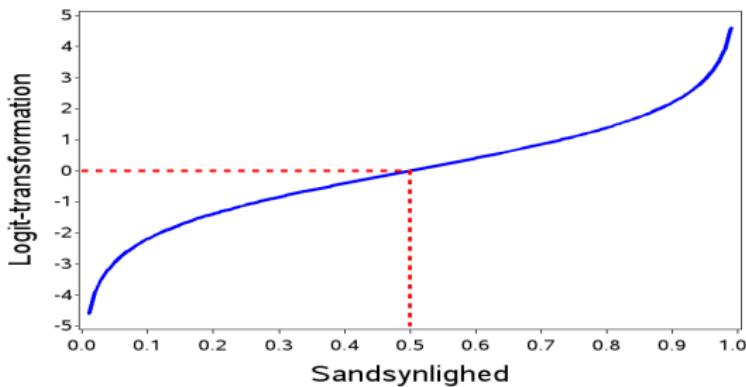
$$\eta_i = g(p_i) = \beta_0 + \beta_1 \text{alder}_i + \beta_2 \text{over2timer}_i$$

Den hyppigst anvendte funktion er **logit-funktionen**, og analysen kaldes derfor **logistisk regression**:

$$\eta_i = g(p_i) = \text{logit}(p_i) = \log\left(\frac{p_i}{1 - p_i}\right)$$



# Logit funktionen



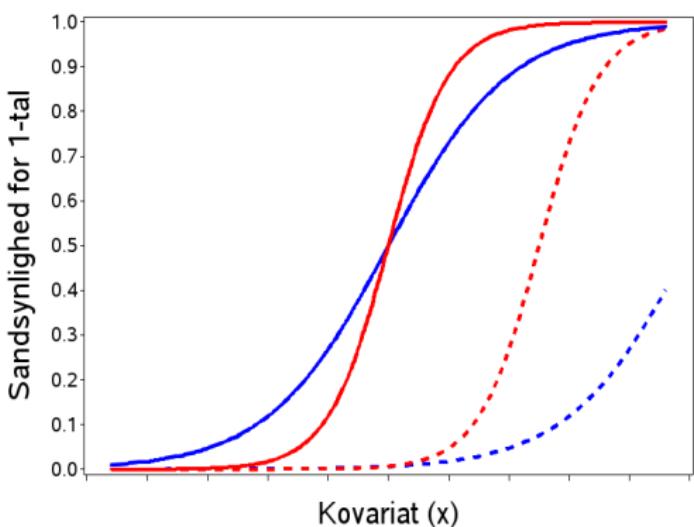
Sandsynligheder tæt på 0 giver store negative logit-værdier,  
Sandsynligheder tæt på 1 giver store positive logit-værdier

Så på denne skala giver det mening at bygge lineære modeller



# Logistiske kurver – for en enkelt kovariat, $x$

$$p(x) = g^{-1}(\eta) = \frac{\exp(\beta_0 + \beta_1 x)}{1 + \exp(\beta_0 + \beta_1 x)}$$



- ▶  $\beta_0: -5, 0$
- ▶  $\beta_1: 1, 2$



## Fortolkning af parametre - for en enkelt kovariat

Model:  $Y_i \sim \text{Binomial}(1, p_i)$ , hvor  $\text{logit}(p_i) = \beta_0 + \beta_1 x_i$

Sammenlign to personer, A og B, med alder  $x_A = a$  hhv.  $x_B = a + 10$ , altså med en aldersforskelse på 10 år:

Person B:  $\text{logit}(p_B) = \beta_0 + \beta_1 \times (a + 10)$

Person A:  $\text{logit}(p_A) = \beta_0 + \beta_1 \times a$

Forskelse:  $\text{logit}(p_B) - \text{logit}(p_A) = \beta_1 \times 10$

Men  $\text{logit}(p_B) - \text{logit}(p_A) = \log(OR)$

og derfor er **Odds Ratio** for infektion for person B vs. person A netop

$OR = \exp(\beta_1 \times 10)$ , fordi der var 10 års forskel på de to personer.



## Fortolkning af parametre - for to kovariater

Nu er

$$\text{logit}(p_i) = \beta_o + \beta_1 x_{1i} + \beta_2 x_{2i}$$

Sammenlign igen to personer, A og B, med alder  $x_{1A} = a$  hhv.  
 $x_{1B} = a + 10$ , altså med en aldersforskelse på 10 år,  
men **samme operationsvarighed(sgruppe)**  $x_{2A} = x_{2B} = b$ :

Person B:  $\text{logit}(p_B) = \beta_o + \beta_1 \times (a + 10) + \beta_2 \times b$

Person A:  $\text{logit}(p_A) = \beta_o + \beta_1 \times a + \beta_2 \times b$

Forskelse:  $\text{logit}(p_B) - \text{logit}(p_A) = \beta_1 \times 10$

altså **samme svar** som ved en enkelt kovariat,  
*ganske som i almindelig regression*



# Fortolkning af parametre, fortsat

## Fortolkning af interceptet, $\beta_0$

- ▶ har (som altid) noget at gøre med en person, hvor alle kovariater er 0, nemlig  $\log(\frac{p}{1-p})$  for en sådan person.
- ▶ dvs. her en nyfødt (alder=0), der har en operationstid på under 2 timer (over2timer=0)

Dette er irrelevant!

For at få et fortolkeligt intercept, kan vi i stedet **centrere** alderen ved f.eks. 50 år, altså benytte kovariaten

alder\_minus50=alder-50

eller prediktere for denne udvalgte alder



# Software til logistisk regression

- ▶ SAS
  - ▶ LOGISTIC: let, kan anvendes til ordinale data  
<http://www.ats.ucla.edu/stat/sas/dae/logit.htm>
  - ▶ GENMOD: minder om GLM, kan anvende andre links og andre fordelinger, men kræver lidt mere kodning  
<http://support.sas.com/kb/42/728.html>
- ▶ SPSS: Analyze/Regression/Binary Logistic  
<https://www.youtube.com/watch?v=zj15KUXtC7M>  
<http://www.ats.ucla.edu/stat/spss/topics>
- ▶ R: glm  
<http://www.statmethods.net/advstats/glm.html>
- ▶ STATA: logit  
<http://www.ats.ucla.edu/stat/stata/dae/logit.htm>



# Software til logistisk regression - HUSK

Hvis man ikke passer på, kommer man til at benytte en sædvanlig normalfordelingsmodel

– ikke så smart, når outcome kun kan være 0 eller 1

Sørg for at få specifceret:

- ▶ Fordelingen: Binomial eller Bernoulli (Binomial med N=1) (family=binomial)
- ▶ Link-funktionen, der vælger hvilken skala, vi benytter til den lineære struktur, sædvanligvis *logit* (link="logit"), men evt. en anden — hvis man har styr på, hvad man gør
- ▶ hvad “event” er, altså om man vil modellere sandsynlighed for et 1-tal eller et 0 (R vælger at modellere sandsynligheden for et 1-tal)



# Logistisk regression i praksis

Vi lægger modelresultatet i model1:

```
model1 = glm(formula=infektion ~  
             factor(over2timer)+alder,  
             family=binomial(link="logit"), data=inf)
```

hvorefter vi kan benytte funktioner såsom

```
summary(model1)  
confint(model1)  
drop1(model1, test = "Chisq")
```



# Output fra logistisk regression

```
> summary(model1)

Call:
glm(formula = infektion ~ factor(over2timer) + alder, family = binomial(link = "logit"),
     data = inf)

Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept) -4.73658   1.07867 -4.391 1.13e-05 ***
factor(over2timer)1 1.32921   0.47295  2.810  0.00495 **
alder        0.03548   0.01491  2.379  0.01734 *

```

Selve parameterestimaterne er på log-odds skala, og derfor ikke umiddelbart fortolkelige, pånær fortegnet.

Se i stedet på Odds-ratio herunder (jvf s. 18-19)

```
> cbind(exp(coef(model1)),exp(confint(model1)))
Waiting for profiling to be done...
              2.5 %      97.5 %
(Intercept) 0.008768596 0.0007057854 0.05281793
factor(over2timer)1 3.778073411 1.4916906798 9.68216684
alder       1.036119878 1.0093289803 1.07145168
```



## Kommentarer til output


Fokus er på Odds-ratio (dvs. **forholdet mellem odds**) for komplikation **mellem to niveauer** af en kovariat, **for fastholdt værdi af de øvrige kovariater**

- ▶ Personer med en operationsvarighed over 2 timer har en odds for sårinfektion, der er 3.78 gange højere end dem med en operationsvarighed under 2 timer **på samme alder** (CI: 1.49, 9.68).
- ▶ For en patientpopulation, der har alderen  $X+10$  år, vil odds (forholdet mellem patienter der får hhv. ikke får sårinfektion) være en faktor  $1.036^{10} = 1.42$  større end hos en patientpopulation, der har alderen  $X$  år (forudsat at de to populationer har **lige lang operationstid**). Det svarer til, at odds er øget med 42%, med CI: 9.7%-99.4% (tilbagetransformeret fra  $1.009^{10}$  hhv.  $1.071^{10}$ )




# Predikterede sandsynligheder for postoperativ sårinfektion

På sandsynligheds-skala



På logit-skala



Kurverne er (parallelle) rette linier på logit-skala

Kode til dette s. 98-99



## \*Inhomogene populationer

Ofte er der uerkendte kovariater (kunne f.eks. være køn), og så er der større forskel på personerne end modellen angiver (overspredning)

### Effekt af manglende kovariater

- ▶ De “*sædvanlige*” pga confounding
- ▶ De “*nye*”, som skyldes ikke-linearitet af logit-funktionen
  - ▶ Undervurdering af effekter, her alder
  - ▶ Undervurdering af standard errors

Det, modellen udtaler sig om, er nemlig en sammenligning af 2 personpopulationer (**af blandet køn**) med forskellig alder – og det giver ikke nødvendigvis det samme som en tilsvarende sammenligning, opdelt på køn.



## Et simpelt eksempel

med tænkte sandsynligheder (f.eks. for infektion) ved alder 30 og 40 år, for hhv. mænd og kvinder:

Køn	30 år	40 år	Differens	log(OR)	OR
Mænd	0.2	0.4	0.2	0.981	2.67
Kvinder	0.6	0.8	0.2	0.981	2.67
Alle	0.4	0.6	0.2	0.811	2.25

Begge køn har  $OR=2.67$  for infektion ved 40 år i forhold til ved 30 år, men på “populationsniveau” har vi  $OR=2.25$

Gennemsnittet af subpopulationernes OR'er (som her for nemheds skyld er ens) er altid større end OR udregnet for hele populationen.



# Konsekvens for randomiserede undersøgelser

Her er der pr. definition *ingen* confounding,  
men størrelsen af Odds Ratio for behandlingseffekt  
*kan alligevel afhænge af populationssammensætningen!*

- ▶ Hvis der er restriktive inklusionskriterier,  
bliver OR formentlig stort
- ▶ Hvis der "blot" er samplet revl og krat,  
bliver OR formentlig mindre

Det er altså helt og holdent spørgsmålets præcisering, der afgør svaret....

Det er ikke evidensen (P-værdien), der refereres til,  
men selve estimatet.



# Confounding og inhomogeniteter

Hvad hvis vi sammenligner to populationer med 10 års forskel *uden at tage hensyn til operationstid*, dvs. kun med alder som kovariat?

Så får vi formentlig noget

- ▶ **større**, fordi der er *confounding* mellem alder og operationstid, idet de ældre generelt har længere operationstid

	over2timer	alder.mean	alder.min	alder.max
1	0	52.40132	7	90
2	1	68.88095	31	90

- ▶ **mindre**, fordi vi tager gennemsnit over nogle mere inhomogene populationer

(Forskellen er dog ikke stor, se venstre kolonne af tabel s. 31)



# OR estimerer for infektion i forskellige modeller

Outcome: infektion	Effekt af	
Kovariater i model	10 år ældre OR (CI)	operationstid > 2 timer OR (CI)
kun alder	1.48 (1.13, 1.93) P=0.0043	–
kun over2timer	–	5.13 (2.07, 12.71) P=0.0004
alder og over2timer	1.42 (1.097, 1.994) P=0.017	3.78 (1.49, 9.68) P=0.0050



# Tilbage til modellen

Var den fornuftig ud fra et anvendelses-synspunkt?

1. Fik vi stillet et relevant spørgsmål?
  - det stod forhåbentlig i protokollen
2. Fik vi opstillet en model,  
der tillod at besvare dette spørgsmål?
  - var det f.eks. en **interaktion**, der var i fokus?
3. Har vi leveret et fyldestgørende svar?  
og har vi husket at kvantificere, med konfidensinterval?

Og så er der jo lige det med **modelkontrol**.....:

Har vi modelleret det så tilpas godt, så vi også *tror* på svaret?



# Interaktion

Har operationsvarigheden en *større* betydning for ældre mennesker end for yngre?

Inkluder interaktionen mellem operationsvarighed og alder, i form af effekten over2timer:alder (kode s. 100)

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )	
(Intercept)	-4.94854	1.28631	-3.847	0.00012	***
factor(over2timer)1	2.19979	2.47794	0.888	0.37468	
alder	0.03853	0.01779	2.165	0.03037	*
factor(over2timer)1:alder	-0.01230	0.03445	-0.357	0.72103	


Her ser vi kun på P-værdierne

Hvis (når) vi vil vide noget om Odds Ratioer, må vi selv specificere yderligere...eller opdele




# Interaktion mellem alder og operationsvarighed

På sandsynligheds-skala



På logit-skala



Der ses ikke nogen tegn på interaktion ( $P=0.72$ ), se s. 33



# Modelkontrol

Vi havde oprindeligt antaget **additivitet** mellem alder og operationsvarighed, samt **linearitet** for alderseffekten (på logit-skala).

## Numerisk modelkontrol:

- ▶ Overall goodness of fit (s. 36-38, kode s. 101)

- ▶ **Linearitet:**

Tilføj logaritmeret kovariat, Lineære splines,  
eller evt. kvadratled ("velkendt", s. 39-42, kode s. 102-103)

- ▶ **Additivitet:**

Check for interaktion (har vi lige gjort s. 33-34, "velkendt")

## Grafisk modelkontrol:

- ▶ Residualplots (s. 43-45)
- ▶ Diagnostic plots (s. 46-47)



## \* Overall Goodness-of-fit

for modellen s. 23 (se kode s. 101)

- ▶ Observationerne inddeltes i 10 ca. lige store grupper, baseret på stigende predikteret sandsynlighed for infektion
- ▶ I hver gruppe sammenlignes observerede og forventede antal af infektioner, og
- ▶ Størrelserne  $\frac{(OBS - N\hat{p})^2}{N\hat{p}(1-\hat{p})}$  sammenlægges til en **approksimativ**  $\chi^2$ -teststørrelse med 8 frihedsgrader (antal grupper minus 2)

Her finder vi  $\chi^2 = 7.50 \sim \chi^2(8) \Rightarrow P = 0.48$  og dermed intet tegn på problemer med modellen



# Goodness-of-fit i praksis

sædvanligvis kaldt **Hosmer-Lemeshow**-testet. Dette kræver en "add-on" pakke:

```
install.packages("ResourceSelection")
library(ResourceSelection)

hl = hoslem.test(inf$infektion, fitted(model2), g=10)
```

## Bemærk:

I tilfælde af sparsomme data kan inddelingen have en del indflydelse på testet, dvs. ***det er meget ustabilt***. F.eks. kan det ændre sig, hvis man skifter til at se på det modsatte outcome, altså event="0" (her P=0.13 vs. P=0.48).



# Output fra Hosmer-Lemeshow testet

Se kode foregående side

```
> hl
Hosmer and Lemeshow goodness of fit (GOF) test

data: inf$infektion, fitted(model2)
X-squared = 7.5046, df = 8, p-value = 0.4833

> cbind(hl$observed,hl$expected)
      y0   y1   yhat0   yhat1
[0.0092,0.0151] 21   1 21.73221 0.2677906
(0.0151,0.0182] 21   0 20.63792 0.3620831
(0.0182,0.0296] 15   0 14.66526 0.3347357
(0.0296,0.0749] 20   0 18.93914 1.0608598
(0.0749,0.102]  18   3 19.11427 1.8857349
(0.102,0.124]   15   2 15.04375 1.9562545
(0.124,0.139]   19   4 19.99388 3.0061220
(0.139,0.191]   15   1 13.45090 2.5490981
(0.191,0.303]   13   7 14.87914 5.1208598
(0.303,0.404]   14   5 12.54354 6.4564615
```

Med en P-værdi på 0.48 ses ingen generel afvigelse fra modellen  
**men testet er som nævnt meget ustabilt ved små datasæt**



# Alderseffekt modelleret med både alder og log(alder)

$$\text{logit}(p) = \beta_0 + \beta_1 \cdot 1_{\text{optid}>2} + \beta_2 \cdot (\text{alder}-50) + \beta_3 \cdot (\log_{1.1}(\text{alder}) - \log_{1.1}(50))$$

Se kode s. 102

```
> summary(model3)
```

```
Call:
glm(formula = infektion ~ factor(over2timer) + alder.minus50 +
    logalder50, family = binomial(link = "logit"),
    data = inf, na.action = na.exclude)
```

Coefficients:	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-3.20987	0.57313	-5.601	2.14e-08 ***
factor(over2timer)1	1.39310	0.48747	2.858	0.00427 **
alder.minus50	0.06927	0.05104	1.357	0.17472
logalder50	-0.15144	0.21136	-0.716	0.47368

```
> cbind(exp(coef(model3)), exp(confint(model3)))
```


	2.5 %	97.5 %		
(Intercept)	0.0403619	0.01174104	0.1141373	
factor(over2timer)1	4.0273194	1.55451983	10.6900590	<-----
alder.minus50	1.0717232	0.95754902	1.1792414	
logalder50	0.8594711	0.59978978	1.4497293	

Meget ringe indikation af afvigelse fra linearitet ( $P = 0.47$ )




# Effekten af alder og log(alder)

På sandsynligheds-skala



På logit-skala



# Effekten af alder som lineær spline

med knæk ved 60 og 75 år får vi **outputtet** (kode s. 103):

```
> summary(model4)
```

Call:

```
glm(formula = infektion ~ factor(over2timer) + alder + alder.over60 +
    alder.over75, family = binomial(link = "logit"),
    data = inf, na.action = na.exclude)
```

Coefficients:	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-4.69328	1.60934	-2.916	0.00354 **
factor(over2timer)1	1.31426	0.49053	2.679	0.00738 **
alder	0.02841	0.03323	0.855	0.39260
alder.over60	0.07302	0.08186	0.892	0.37240
alder.over75	-0.20019	0.12292	-1.629	0.10340


```
> cbind(exp(coef(model4)),exp(confint(model4)))
              2.5 %    97.5 %
(Intercept) 0.009156558 0.0001282662 0.1133436
factor(over2timer)1 3.721984866 1.4281607678 9.9363844 <-----
alder        1.028819014 0.9696274894 1.1141968
alder.over60 1.075753440 0.9185984486 1.2746073
alder.over75 0.818578804 0.6324346966 1.0293964
```

En vis indikation for afvigelse fra linearitet ved 75 år ( $P = 0.10$ ),  
**men...**




# Effekten af alder som lineær spline

På sandsynligheds-skala



På logit-skala




Intet signifikant knæk, men dog en tendens.....

Tror vi på den?



# Modelkontrol

Den sædvanlige konstruktion af residualer ( $r_i = y_i - \hat{p}_i$ ) giver nogle forfærdeligt grimme figurer, f.eks. (se kode s. 104)




og her er endda standardiseret til  $e_i = \frac{r_i}{\sqrt{\hat{p}_i(1-\hat{p}_i)}}$



## Modelkontrol, fortsat

Der kan være en fordel i at se på **kumulerede residualer**, kumuleret fra lave til høje aldre (se kode s. 105):



Her er indlagt 40 forløb, simuleret under forudsætning af en korrekt model. **Falder det aktuelle (fed streg) forløb udenfor?**



## Modelkontrol, fortsat

Figuren på forrige side kan vurderes visuelt, men man kan også lave et **numerisk check** på den maksimale afvigelse fra 0, her baseret på 1000 simulationer.


Vi finder  $P=0.36$  (fremgår af selve figuren), og dermed ingen evidens for en gal modellering af alderseffekten.

Koden ses på s. 105



## Diagnostics – Cooks afstand

Cooks afstand: (mål for den enkelte observations indflydelse på estimerne), her plottet op mod observationsnummeret (kode s. 106)




Bemærk den enkelte observation med stor Cook, som i R placeres for sig selv.




# Diagnostic plots (kode s. 106)

Cooks afstand vs. alder  
blå: lang operationstid



Effekt på alders-estimat  
vs. alder, blå: infektion



Her kan vi se, at observationen med stor indflydelse er ung, med en kort operationstid, men med infektion



# Den suspekte person

findes at være person nr. 93:

```
> inf[cook1==max(cook1),]  
    id infektion optid alder over2timer alder.minus50 logalder50 alder_over60  
93 93          1     55     12          0         -38   -14.97339          0  
    alder_over75 alder.over60 alder.over75 resid1  
93          0          0          0  8.631275
```

Det drejer sig altså om en 12-årig patient, der til trods for kort operationstid, *alligevel* får en infektion.

Det er usædvanligt, og derfor ændres estimaterne en del, hvis denne patient pilles ud.

Og hvilken begrundelse kunne der også være for det?



# Konklusion

baseret på resultater fra s. 24, reproduceret her:

```
> cbind(exp(coef(model1)),exp(confint(model1)))
              2.5 %    97.5 %
(Intercept) 0.008768596 0.0007057854 0.05281793
factor(over2timer)1 3.778073411 1.4916906798 9.68216684
alder        1.036119878 1.0093289803 1.07145168
```

- ▶ Sample size er lidt for lille til, at man kan udtale sig meget sikkert omkring alderseffekten, men risikoen *ser ud til* at stige med alderen.
- ▶ Det er bedst at have en lav operationsvarighed (*surprise* 😱) *hvor meget bedre* er dog ret usikkert (bredt konfidensinterval)



# Odds ratio, Risk ratio og Risk differenser

Den **link-funktion**, der anvendes, afgør hvilket mål, der kommer ud af det

- ▶ logit-link er *default*, giver **Odds Ratio**  
det brugte vi for at modellere infektioner  
Dette link skal *altid* benyttes ved case-control studier.
- ▶ log-link giver **Risk Ratio** (relativ risiko)  
det kunne vi f.eks. bruge på data vedr. **farveblindhed**  
(s. 51-52)
- ▶ identity-link giver **Risk difference**  
det kan vi bruge til at lave trend test for  
**kejsersnit vs. skostørrelse** (s. 53ff)

logit er default, fordi det sikrer, at vi ikke kommer udenfor intervallet (0,1) med sandsynlighederne



## Farveblindhed - igen

Risk Ratio (relativ risiko) estimeres ved at benytte log-link:

```
gender = as.factor(c(rep("Piger",120),rep("Drenge",150)))
farve = c(rep("nej",119),rep("ja",1),rep("nej",144),rep("ja",6))

farveblind=(farve=="ja")

model1 = glm(farveblind ~ relevel(gender,ref="Piger"),
family=binomial(link="log"))
```

Nederste linie af output på næste side viser, at den **relative risiko for farveblindhed for drenge vs. piger** er estimeret til 4.80, med konfidensgrænser (0.84, 90.01), altså *ingen signifikant forskel* ( $P=0.14$ ), og en **meget usikker** bestemmelse af den relative risiko.



# Output fra analyse med log-link

```
> summary(model1)
```

Call:

```
glm(formula = farveblind ~ relevel(gender, ref = "Piger"),
family = binomial(link = "log"))
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-4.7875	0.9955	-4.809	1.52e-06 ***
relevel(gender, ref = "Piger")Drenge	1.5686	1.0729	1.462	0.144
(Dispersion parameter for binomial family taken to be 1)				

```
> cbind(exp(coef(model1)),exp(confint(model1)))
```

	2.5 %	97.5 %
(Intercept)	0.008333335	0.000477164
relevel(gender, ref = "Piger")Drenge	4.799999225	0.835307130
	90.0068868	

# eller med Wald-baseret konfidensinterval:

```
> cbind(exp(coef(model1)),exp(confint.default(model1)))
```

	2.5 %	97.5 %
(Intercept)	0.008333335	0.001184171
relevel(gender, ref = "Piger")Drenge	4.799999225	0.586129194
	39.30872716	

Se kommentarer til output på forrige side



## Eksempel om kejsersnit vs. skostørrelse


351 fødende kvinder har fået registreret deres skostørrelse, samt om et kejsersnit blev aktuelt ved fødslen.

Kejsersnit	Skonummer						Total
	< 4	4	4.5	5	5.5	≥ 6	
Ja	5	7	6	7	8	10	43
Nej	17	28	36	41	46	140	308
I alt	22	35	42	48	54	150	351
% kejsersnit	22.7	20.0	14.3	14.6	14.8	6.7	12.3

Vi kunne have en hypotese om **faldende sandsynlighed for kejsersnit med stigende (sko)størrelse**



# Frekvens af kejsersnit som funktion af skostørrelse



Måske er der linearitet i skostørrelse?

Dette *kunne* gå an her, fordi vi ikke er tæt på 0....



# Test for trend

Modellen *antager* linearitet i skostørrelse:  $p_i = \alpha - \beta \times \text{sko}_i$

og estimationen udføres som en regression i Binomial-fordelingen, med identity-link.

```
skonummer = c(rep(3.5,22),rep(4,35),rep(4.5,42),rep(5,48),
               rep(5.5,54),rep(6,150))
snit = c(rep("ja",5),rep("nej",17),rep("ja",7),rep("nej",28),rep("ja",6),rep("nej",36),
         rep("ja",7),rep("nej",41),rep("ja",8),rep("nej",46),rep("ja",10),rep("nej",140))
```

```
> table(skonummer,snit)
      snit
skonummer   ja nej
  3.5      5 17
  4        7 28
  4.5     6 36
  5        7 41
  5.5     8 46
  6       10 140
```

```
kejsersnit=(snit=="ja")
```

```
model2 = glm(kejsersnit ~skonummer,
             family=binomial(link="identity"))
```



# Output: Test for trend

altså med linearitet på selve sandsynligheds-skalaen

```
> summary(model2)
```

Call:

```
glm(formula = kejsersnit ~ skonummer, family = binomial(link = "identity"))
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	0.45607	0.12662	3.602	0.000316 ***
skonummer	-0.06356	0.02281	-2.786	0.005337 **

```
> confint(model2)
```

	2.5 %	97.5 %
(Intercept)	0.2162037	0.7221782
skonummer	-0.1107865	-0.0190242

Ekstra risiko for kejsersnit, når skoene er et nummer **mindre**:  
0.0636, CI=(0.0190, 0.1108), altså mellem 1.9% og 11.1%



# Trick: Modelkontrol af lineariteten

Lineariteten i skonummer var jo *en antagelse*.

**Trick** (i alle former for regression):

Når kovariaten kun antager så få værdier, kan linearitetsantagelsen checkes ved at sætte en kopi af skonummer ind som faktor oveni, og så teste, om denne kan undværes:

```
model3 = glm(kejsersnit ~ skonummer + factor(skonummer),  
             family=binomial(link="identity"))  
  
anova(model3,test="LR")
```

Modellen ville være den samme, hvis skonummer blev udeladt, men så ville vi ikke få testet, om modellen med **kun skonummer** var fornuftig



# Output fra check af linearitet

```
> anova(model3,test="LR")
Analysis of Deviance Table

Model: binomial, link: identity
Response: kejsersnit

Terms added sequentially (first to last)

          Df Deviance Resid. Df Resid. Dev Pr(>Chi)
NULL           350      261.07
skonummer     1    8.0502    349      253.02  0.00455 ** 
factor(skonummer) 4    1.2940    345      251.72  0.86240
```

## Bemærk:

- Man kan *ikke* teste skonummer væk fra modellen, da dette ikke ændrer modellen.

**Det ovenstående test er i en model med *kun* skonummer**

- Man kan *godt* teste factor(skonummer) væk fra modellen, da man derved reducerer til en lineær effekt af skonummer

**Lineariteten i skonummer ser rimelig ud ( $P=0.86$ )**



# Typer af outcome

## Hidtil

- ▶ Kvantitative, Den generelle lineære model
- ▶ Dikotom (0/1), Logistisk regression

Nu følger en lille smule om:

- ▶ **Ordinale outcomes**  
f.eks. fysisk formåen på en skala 1-2-3-4  
*og måske kan vi også nå (s. 79ff)*
- ▶ **Tælletal** (uden øvre grænse), f.eks. antal metastaser  
*Poisson regression eller log-lineære modeller*



# Eksempel om leverfibrose

Ordinalt outcome: Leverfibrose, grad 0,1,2 eller 3

Kovariater:

3 blodmarkører relateret til fibrose: HA, YKL40, PIIINP

Problemstilling:

Hvad kan vi sige om fibrosegrad ud fra måling af disse 3 blodmarkører?

```
> summary(fib[3:6],)
   ykl40          piiinp         ha      fibrosegrad
Min.   : 50.0   Min.   : 1.70   Min.   : 21.0   0:27
1st Qu.: 175.0  1st Qu.: 5.15   1st Qu.: 30.0   1:40
Median : 330.0  Median : 9.00   Median : 105.5  2:42
Mean   : 533.5  Mean   :13.41   Mean   : 318.5  3:20
3rd Qu.: 718.0  3rd Qu.:15.85  3rd Qu.: 250.5
Max.   :4850.0   Max.   :70.00   Max.   :4730.0
NA's    :2        NA's    :1
```

(Julia Johansen, KKHH)

60 / 114



# Ordinale data

- ▶ data på en rangskala
- ▶ afstand mellem responskategorier kendes ikke, eller er udefineret
- ▶ evt. en underliggende kvantitativ skala




## Vi sidder mellem to stole:

- ▶ Vi kan reducere til et binært respons og lave logistisk regression
  - men vi kan opdele flere steder
- ▶ Vi kan 'lade som om' det er normalfordelt
  - virker naturligvis bedst hvis der er mange responskategorier



# Fordeling af blodmarkører

vist for hver fibrose kategori

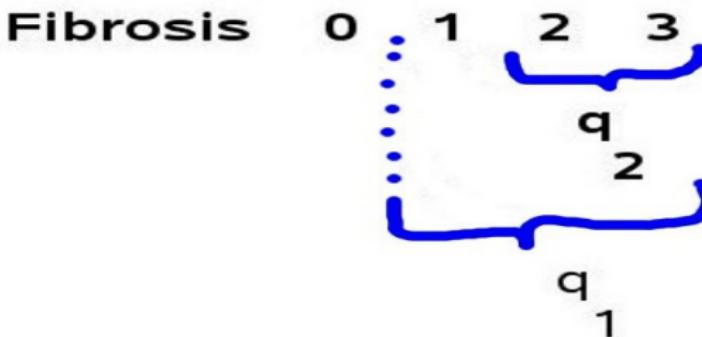


Er der noget problem ved de meget skæve fordelinger?



# Kumulerede sandsynligheder

Sandsynlighed for *dette eller værre*



Tilbageregning til sandsynligheder for de enkelte fibrosegrader:

$$p_0 = 1 - q_1, \quad p_1 = q_1 - q_2$$

$$p_s = q_s - q_3, \quad p_3 = q_3$$



# Proportional odds model

*Logistisk regression* for hver tærskel,  
med **samme afhængighed** af kovariaterne, dvs.

$$\text{logit}(q_3) = \beta_{03} + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

$$\text{logit}(q_2) = \beta_{02} + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$


$$\text{logit}(q_1) = \beta_{01} + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$

Her er kovariaterne de 3 biomarkører, alle  $\log_2$ -transformerede:  
Odds ratio vil **ikke afhænge af cutpoint**,  
og denne antagelse testes automatisk som  
*Proportional odds assumption*



# Illustration af predikterede sandsynheder

i tilfælde af **en enkelt** kovariat



## Model med alle tre kovariater

alle logaritmetransformeret ( $\log_2$ ):

```
library(MASS)
```

```
m <- polr(fibrosegrad ~ lha + lpiiinp + lykl40, data = fib, Hess=TRUE)
```

som giver outputtet på næste side

Vi ville egentlig også gerne have et test for antagelsen om proportional odds, men det vil R ikke umiddelbart give, da det siges at give for stor sandsynlighed for forkastelse. I SAS får vi:

```
Score Test for the Proportional Odds Assumption  
Chi-Square      DF      Pr > ChiSq  
    9.6967        6       0.1380
```

som siger, at antagelsen om *proportional odds* ikke er direkte forkert



# Output fra ordinal regression i R

```
> summary(m)
Call:
polr(formula = fibrosegrad ~ lha + lpiiinp + lykl40, data = fib,
      Hess = TRUE)

Coefficients:
            Value Std. Error t value
lha       0.3891    0.1660   2.344
lpiiinp  0.8224    0.2602   3.161
lykl40    0.5429    0.1667   3.257

Intercepts:
            Value Std. Error t value
0|1     7.5924  1.3651    5.5617
1|2    10.0120  1.5135    6.6151
2|3    12.7770  1.6907    7.5573

Residual Deviance: 246.4663
AIC: 258.4663
(3 observations deleted due to missingness)
```

Koefficienterne for de tre blodmarkører skal tilbagetransformeres for at kunne fortolkes, se næste side.



# Output, fortsat

## Tabel med P-værdier:

```
> ctable=coef(summary(m))
> p <- pnorm(abs(ctable[, "t value"]), lower.tail = FALSE) * 2
> ptable <- cbind(ctable, "p value" = p)

> ptable[1:3,]
  Value Std. Error   t value     p value
lha    0.3890613  0.1660076  2.343635 0.019096839
lpipiinp 0.8223711  0.2601810  3.160766 0.001573551
lykl40  0.5429406  0.1666785  3.257411 0.001124334
```

## Tabel med odds ratio'er:

```
> cbind(exp(coef(m)),exp(confint(m)))
          2.5 %    97.5 %
lha      1.475595 1.073350 2.062009
lpipiinp 2.275890 1.375084 3.829320
lykl40   1.721060 1.246188 2.402576
```


## Eksempel på fortolkning:

En fordobling af markøren ykl40 giver 72.1% større odds for at være i en høj kategori



# Afgigelse fra proportional odds antagelsen?

Helt *frie* logistiske regressioner for hver tærskel giver disse odds ratio'er:






Måske er der lidt forskel på estimatorne for piiinp...

men det var altså ikke signifikant ( $P=0.13$ , se s. 66)



# Hvis der ikke er proportional odds

kan vi få groteske resultater, i form af negative predikterede sandsynligheder....




# Modelkontrol

Der er flere ting, der skal checkes:

- ▶ **lineariteten** af kovariat-effekterne,  
på logit-skalaen, *ligesom for logistisk regression*,  
men der er mange residualplots:  
Et for hver kombination af fibrosegrad og kovariat,  
dvs. 12 i alt.
- ▶ **proportional odds** antagelsen
- ▶ modellens evne til faktisk at prediktere en fornuftig fibrosegrad




# Residualplot for ha



Svag afvigelse fra linearitet




# Residualplot for p3np



Nogen afvigelse fra linearitet



# Residualplot for ykl40



Rimelig lineæritet



# Diagnostics

De farvede observationer skal man måske se lidt nærmere på:

- ▶ Tre gule for grad 0
  - som *burde* have haft en højere grad,  
baseret på deres ret høje kovariat-værdier
    - specielt for p3np
- ▶ En enkelt grøn for grad 1
  - som *burde* have haft en højere grad,  
baseret på de meget høje kovariat-værdier
    - specielt for ha
- ▶ To turkise for grad 2
  - som *burde* have haft en lavere grad,  
baseret på de forholdsvis lave kovariat-værdier
    - specielt for ha



## Predikterede sandsynligheder

For hver person kan værdierne af de 3 blodmarkører benyttes til at prediktere sandsynligheder for hver af de 4 fibrosegrader.


Vi ser gerne, at disse *passer med* de faktiske fibrosegrader, altså at den predikterede sandsynlighed for den observerede fibrosegrad er så høj som muligt.

På s. 77 ses en figur, hvor

- ▶ X-aksen viser faktisk observeret fibrosegrad
- ▶ For alle personer med en bestemt observeret fibrosegrad (f.eks. 2) udregnes nu gennemsnitlig predikteret sandsynlighed for hver af de 4 fibrosegrader, og disse afsættes som punkter op ad Y-aksen. Det røde punkt svarer til den predikterede sandsynlighed for grad 2, som jo svarer til den observerede og derfor gerne skulle være høj.



## Predikterede sandsynligheder, II



Værdierne svarende til den **korrekte fibrosegrad** er røde,  
og de skulle gerne være høje



# Observeret vs. predikteret fibrosegrad

Table of degree\_fibr by pred\_grad


degree\_fibr      pred\_grad

		Frequency				Total
Col	Pct	0	1	2	3	
0		13	12	1	0	26
		59.09	29.27	1.96	0.00	
1		8	21	9	0	38
		36.36	51.22	17.65	0.00	
2		1	7	27	7	42
		4.55	17.07	52.94	58.33	
3		0	1	14	5	20
		0.00	2.44	27.45	41.67	
Total		22	41	51	12	126



# Tælletal

Antal dræbte i trafikken fra 2004-2014, kønsopdelt,  
fra Danmarks Statistik



Vi lader  $Y_{gt}$  (total) betegne antallet af trafikdræbte med køn  $g$  (gender) og tid  $t$  (years\_from\_2004), i alt 22 observationer og 3 variable.



# Binomialfordeling, med approksimationer

Hvis vi *vidste*, hvor mange personer, der var utsat for at blive dræbt i trafikken ( $N_{gt}$ , afhængig af køn  $g$  og årstal  $t$ ), kunne vi modellere antal dræbte som en Binomialfordeling

$$Y_{gt} \sim \text{Bin}(N_{gt}, p_{gt})$$

men vi kender ikke  $N_{gt}$ , vi ved bare, at den er stor, og at  $p_{gt}$  er lille.  
I sådan et tilfælde **approksimeres Binomialfordelingen af en Poisson-fordeling:**

$$P(Y_{gt} = m) = \frac{\lambda_{gt}^m}{m!} \exp(-\lambda_{gt})$$


hvor  $\lambda_{gt} = N_{gt}p_{gt}$  er **middelværdien, og variansen!!.**



# Regression i Poisson-fordelingen

Da middelværdien af tælletal skal være ikke-negativ, men er uden øvre grænse, modellerer vi den på log-skala (**log-link**):

$\log(\lambda_i) = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2}$  hvor kovariaterne her er hhv. køn (gender) og årstal, her angivet som år siden 2004 (years\_since\_2004).



Figuren kunne gøre det rimeligt at se på en lineær effekt af tid, og evt. inkludere en interaktion mellem køn og tid:

**Er der sket et større fald for mænd end for kvinder?**



# Regression i Poisson-fordelingen, II

## Testvenlig kode:

```
model1 = glm(antal ~ gender + years.from2004  
            + gender:years.from2004,  
family=poisson(link="log"),data=total)  
summary(model1)  
anova(model1,test="LR")
```

## Estimationsvenlig kode:

```
model2 = glm(antal ~ gender + gender:years.from2004,  
family=poisson(link="log"),data=total)  
summary(model2)  
cbind(exp(coef(model2)),exp(confint(model2)))
```



# Output fra Poisson-regression

med to separate lineære effekter af tid (mænd og kvinder),  
dvs. en **interaktion**

```
> anova(model1,test="LR")
Analysis of Deviance Table
Model: poisson, link: log
Response: antal
Terms added sequentially (first to last)

          Df Deviance Resid. Df Resid. Dev Pr(>Chi)
NULL                  21      572.77
gender             1    435.50      20     137.27  <2e-16 ***
years.from2004     1     88.09      19      49.18  <2e-16 ***
gender:years.from2004 1      0.52      18      48.66  0.4688
```

```
> cbind(exp(coef(model2)),exp(confint(model2)))[3:4,]
```

	2.5 %	97.5 %	
genderK:years.from2004	0.9153843	0.8605032	0.9724935
genderM:years.from2004	0.8932410	0.8709227	0.9158761

Vi ser et estimat på ca. 10% reduktion pr. år (**faktorerne 0.8932 hhv. 0.9154**), nogenlunde ens for mænd og kvinder ( $P=0.47$ ).



# Model uden interaktion

Vi udelader den insignifikante interaktion:

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )	
(Intercept)	2.88145	0.11262	25.585	<2e-16	***
genderM	1.80250	0.10386	17.356	<2e-16	***
years.from2004	-0.10939	0.01186	-9.219	<2e-16	***

```
> cbind(exp(coef(model3)),exp(confint(model3)))[2:3,]
```

Waiting for profiling to be done...

	2.5 %	97.5 %
genderM	6.0648148	4.9714262
years.from2004	7.4724675	0.8963825

0.8756712 0.9173715

Begge effekter (køn og årstal) er signifikante:

- ▶ Ca. 10% fald i risiko pr. år
- ▶ Mænd har en ca. 6 gange så stor risiko som kvinder



# Problemer med Poisson-fordelingen

Det er mere reglen end undtagelsen, at Poisson-fordelingen passer dårligt, fordi variansen er større end middelværdien  
(i Poisson-fordelingen er disse *ens*, som nævnt s. 80)

Vi har altså meget ofte **overspredning**:

- ▶ formentlig pga oversete kovariater
- ▶ med den konsekvens, at standard errors undervurderes
- ▶ og der findes **alt for stærke signifikanser**

Korrektion for overspredning (baseret på deviance)

```
model3.quasi = glm(antal ~ gender + years.from2004,  
family=quasipoisson(link="log") ,data=total)
```



# Output ved korrektion for overspredning

Først selve estimatet for overspredningen:

$$1.5830 = \sqrt{2.5059}$$

(Dispersion parameter for quasipoisson family taken to be 2.505865)

Residual deviance: 49.181 on 19 degrees of freedom

Når der korrigeres for overspredningen, får man lidt bredere konfidensintervaller (sammenlign til s. 84):

```
> cbind(exp(coef(model3.quasi)),exp(confint(model3.quasi)))[2:3,]
```

	2.5 %	97.5 %
genderM	6.0648148	4.4455397
years.from2004	8.4824737	0.8963825
	0.8637131	0.9297486



## Sammenlign med normalfordelingsanalyse

Da vi ikke har nogen antal på 0, kan vi tillade os at analysere **logaritmer**, og da antallene er rimeligt store, kan vi forsøge os med en *almindelig* model, dvs. en model baseret på en normalfordelingsantagelse:

Efter tilbagetransformation finder vi så

```
> model3.nf = lm(logantal ~ gender + years.from2004, data=total)

> cbind(exp(coef(model3.nf)),exp(confint(model3.nf)))[2:3,]
              2.5 %    97.5 %
genderM      6.002605 4.4266945 8.1395410
years.from2004 0.897187 0.8550093 0.9414455
```

hvilket ses kun at være en anelse anderledes end det, vi fandt ved Poisson-analysen s. 86, (inkluderende overspredning).



## Konklusion vedr. trafikuheld

- ▶ Der er flere mænd end kvinder, der bliver dræbt i trafikken, ca. 6 gange så mange
  - ▶ De færdes måske mere?
  - ▶ De er måske mere uforsigtige?
  - ▶ Alder er måske en skjult confounder?  
Det kunne jo være, at der var mange flere mandlige bilister i de yngre aldersklasser... men dette er ikke registreret


[Se mere detaljerede figurer på de næste sider](#)

- ▶ Der er sket en reduktion i antallet af trafikdræbte over årene 2004-2014, ca. 10% pr. år




# Trafikuheld, opdelt på årstal

som funktion af alder:



# Trafikuheld, opdelt efter alder

som funktion af år siden 2004:



# Trafikuheld, kun for 18-24-årige

med korrektion for overspredning på  $1.126 = \sqrt{1.268}$   
(se kode s. 114)

```
> summary(m1.quasi)
```

Call:

```
glm(formula = antal ~ gender + years.from2004 + gender:years.from2004,  
family = quasipoisson(link = "log"), data = trafik18.24)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.74892	0.45635	1.641	0.118
genderM	2.39799	0.47985	4.997	9.34e-05 ***
years.from2004	-0.04226	0.08215	-0.514	0.613
genderM:years.from2004	-0.08084	0.08764	-0.922	0.368

(Dispersion parameter for quasipoisson family taken to be 1.268374)  
Residual deviance: 23.199 on 18 degrees of freedom

Interaktionen er ikke signifikant ( $P=0.37$ ), men vi vil alligevel  
gerne se de to separate estimerter (næste side).



# Trafikuheld for 18-24-årige, fortsat

## Estimationsvenlig model:

```
> m2.quasi = glm(antal ~ gender + gender:years.from2004,  
+   family=quasipoisson(link="log"),data=trafiki18.24)  
  
> cbind(exp(coef(m2.quasi)),exp(confint(m2.quasi)))[3:4,]
```

	2.5 %	97.5 %
genderK:years.from2004	0.9586225	0.8125242
genderM:years.from2004	1.1259631	0.8841774
	0.8320417	0.9379807

Det ser ud som om der er sket en noget større reduktion for mænd end for kvinder, men forskellen er som tidligere nævnt ikke signifikant ( $P=0.36$ )



## Sammenlign med normalfordelingsanalyse

Nu har vi et enkelt år, hvor der ikke er nogen kvinder, der er dræbt i trafikken, og så kan vi ikke bruge en normalfordelingsmodel på logaritmerne....**fordi man ikke kan tage logaritmen til 0**

Desuden er antallene generelt så små, når vi kun ser på en enkelt aldersklasse, at en normalfordelingsapproximation ikke ville være særlig god alligevel....



# APPENDIX

Programbidder svarende til diverse slides:

- ▶ To-gange-to tabeller, s. 95
- ▶ Plot af binære data med loess-udglatning, s. 96
- ▶ Logistisk regression, s. 97-98
- ▶ Modelkontrol, s. 101-105
- ▶ Diagnostics, s. 106
- ▶ Alternative links, s. 107-109
- ▶ Ordinale data, s. 110
- ▶ Tælletal, s. 111-114



# To-gange-to tabeller

## Slide 7-10

```
fb = matrix(c(1,6,119,144), nrow=2)
rownames(fb) = c("Piger", "Drenge")
colnames(fb) = c("ja", "nej")

addmargins(fb)

prop.table(fb,1)*100

chisq.test(fb)$expected
chisq.test(fb)
fisher.test(fb)
prop.test(fb)

install.packages("epitools")
library("epitools")

epitab(fb,method="riskratio",rev="columns")$tab

epitab(fb,method="oddsratio",rev="rows")$tab
```



# Figurer

## Slide 13

Plot af infektion vs. alder, med loess-smoother:

```
inff <-  
read.table("http://publicifsv.sund.ku.dk/~lts/basal/Rdata/bremmel.txt",  
header=T,na.strings=c("."))  
  
inf = inff[order(inff$alder),]  
inf$over2timer = as.numeric(inf$optid > 120)  
  
inf0 <- subset(inf, over2timer==0)  
inf1 <- subset(inf, over2timer==1)  
  
loess0 <- loess(infektion ~ alder, data=inf0, span=0.80)  
pred0 = predict(loess0)  
loess1 <- loess(infektion ~ alder, data=inf1, span=0.80)  
pred1 = predict(loess1)  
  
plot(inf0$alder, inf0$infektion,  
     ylab="infektion", xlab="alder", col="red", cex.lab=1.5)  
lines(inf0$alder, pred0, col = "red", lwd = 3, lty = 1)  
points(inf1$alder, inf1$infektion, col="blue")  
lines(inf1$alder, pred1, col = "blue", lwd = 3, lty = 1)  
legend(20, 0.8, legend=c("over 2","under 2"), pch=16,  
       col=c("blue", "red"), cex=1.5)
```



# Logistisk regression

Slide 23-24

```
model1 = glm(formula=infektion ~  
             factor(over2timer)+alder,  
             family=binomial(link="logit"), data=inf)
```

hvorefte vi kan benytte funktioner såsom

```
summary(model1)  
confint(model1)  
drop1(model1, test = "Chisq")  
  
cbind(exp(coef(model1)),exp(confint(model1)))
```



# Figur af predikterede sandsynligheder

## Slide 26

### Prediktion og figur til højre

```
model1 = glm(formula=infektion ~  
             factor(over2timer)+alder,  
             family=binomial(link="logit"), data=inf,na.action=na.exclude)  
  
pred.0 <- predict(model1)[inf$over2timer==0]  
pred.1 <- predict(model1)[inf$over2timer==1]  
  
pred.00 <- predict(model1)[inf$over2timer==0 & inf$infektion==0]  
pred.01 <- predict(model1)[inf$over2timer==0 & inf$infektion==1]  
pred.10 <- predict(model1)[inf$over2timer==1 & inf$infektion==0]  
pred.11 <- predict(model1)[inf$over2timer==1 & inf$infektion==1]  
  
plot(inf$alder, predict(model1),type="n",  
      ylab="infektion", xlab="alder", cex.lab=1.5)  
points(inf00$alder, pred.00, col="green", cex=2,lwd=2)  
points(inf01$alder, pred.01, col="red", cex=2, lwd=2)  
lines(inf0$alder, pred.0, col = "blue", lwd = 3, lty = 1)  
points(inf10$alder, pred.10, col="green", cex=2, lwd=2)  
points(inf11$alder, pred.11, col="red", cex=2, lwd=2)  
lines(inf1$alder, pred.1, col = "blue", lwd = 3, lty = 1)
```



# Figur af predikterede sandsynligheder, fortsat

## Slide 26

### Figur til venstre, tilbagetransformeret til sandsynligheder

```
ny.0 = data.frame(alder=seq(5,90,0.5),over2timer=0)
ny.1 = data.frame(alder=seq(5,90,0.5),over2timer=1)

ny.0$pred = exp(predict(model1, ny.0))
ny.1$pred = exp(predict(model1, ny.1))

plot(inf$alder, exp(predict(model1)),type="n",
ylab="predicted probability", xlab="alder", col="red", cex.lab=1.5)
points(inf00$alder, exp(pred.00), col="green", cex=2, lwd=2)
points(inf01$alder, exp(pred.01), col="red", cex=2, lwd=2)
lines(ny.0$alder, ny.0$pred, col = "blue", lwd = 3, lty = 1)
points(inf10$alder, exp(pred.10), col="green", cex=2, lwd=2)
points(inf11$alder, exp(pred.11), col="red", cex=2, lwd=2)
lines(ny.1$alder, ny.1$pred, col = "blue", lwd = 3, lty = 1)
```



# Interaktionsmodel

Slide 33

Testvenlig kode:

```
model2 = glm(formula=infektion ~  
             factor(over2timer)+alder+factor(over2timer):alder,  
             family=binomial(link="logit"), data=inf,na.action=na.exclude)  
  
summary(model2)  
cbind(exp(coef(model2)),exp(confint(model2)))
```

Estimationsvenlig kode:

```
model2 = glm(formula=infektion ~  
             factor(over2timer)+factor(over2timer):alder,  
             family=binomial(link="logit"), data=inf,na.action=na.exclude)  
  
summary(model2)  
cbind(exp(coef(model2)),exp(confint(model2)))  
100 / 114
```



# Goodness of fit

Slide 36-38

```
install.packages("ResourceSelection")
library(ResourceSelection)

hl = hoslem.test(inf$infektion, fitted(model2), g=10)

> hl

> cbind(hl$observed,hl$expected)
```



# Check af linearitetsantagelsen for alder

## Slide 39

- ▶ Alderseffekt modelleret med både alder og log(alder) (output s. 39-40). Definer:

```
inf$alder.minus50 = inf$alder - 50
```

```
inf$logalder50=log(inf$alder)/log(1.1)-log(50)/log(1.1)
```

og brug modellen

```
model3 = glm(formula=infektion ~  
factor(over2timer)+alder.minus50+logalder50,  
family=binomial(link="logit"), data=inf,na.action=na.exclude)
```

```
summary(model3)  
cbind(exp(coef(model3)),exp(confint(model3)))
```



# Check af linearitetsantagelsen for alder, II

## Slide 42

- ▶ Alderseffekt modelleret som lineær spline (output s. 41-42):  
Definer

```
inf$alder.over60=(inf$alder>60)*(inf$alder-60)  
inf$alder.over75=(inf$alder>75)*(inf$alder-75)
```

og brug modellen

```
model4 = glm(formula=infektion ~  
factor(over2timer)+alder+alder.over60+alder.over75,  
family=binomial(link="logit"), data=inf,na.action=na.exclude)
```



# Plot af standardiserede residualer

## Slide 43

Modellen er den på s. 23,

```
inf$resid1 <- residuals(model1, "pearson")

inf0 <- subset(inf, over2timer==0)
inf1 <- subset(inf, over2timer==1)

loess0 <- loess(resid1 ~ alder, data=inf0, span=0.80)
pred0 = predict(loess0)
loess1 <- loess(resid1 ~ alder, data=inf1, span=0.80)
pred1 = predict(loess1)

plot(inf$alder, inf$resid1,
ylab="residuals", xlab="alder", type="n", cex.lab=1.5)
points(inf0$alder, inf0$resid1, col="red")
lines(inf0$alder, pred0, col = "red", lwd = 3, lty = 1)
points(inf1$alder, inf1$resid1, col="blue")
lines(inf1$alder, pred1, col = "blue", lwd = 3, lty = 1)
```



# Plot af kumulerede residualer

## Slide 44

Figuren med simulationer af de kumulerede residualer er dannet ved at benytte pakken gof:

```
install.packages("gof")
library(gof)

cumcheck1 = cumres(model1,R=1000,variable="alder")

plot(cumcheck1)
```



# Diagnostics

## Slide 46-47

```
plot(model1,which=4, cex.lab=1.5)

cook1=cooks.distance(model1)

plot(inf$alder,cook1,col=2-inf$over2timer,
ylab="Cook's Distance", xlab="alder", cex.lab=1.5, lwd=2)
legend(60, 0.25, title="varighed", legend=c("over 2","under 2"), pch=16,
       col=c("black", "red"), cex=1.5)

plot(inf$alder,dfbetas(model1)[,3],col=2-inf$infektion,
ylab="DfBeta", xlab="alder", cex.lab=1.5, lwd=2)
legend(20, -0.2, title="infektion",legend=c("ja","nej"), pch=16,
       col=c("black", "red"), cex=1.5)

inf [cook1==max(cook1),]
```



# Relativ risiko for farveblindhed

## Slide 51-52

```
gender = as.factor(c(rep("Piger",120),rep("Drenge",150)))
farve = c(rep("nej",119),rep("ja",1),rep("nej",144),rep("ja",6))

farveblind=(farve=="ja")

model1 = glm(farveblind ~ relevel(gender,ref="Piger"),
             family=binomial(link="log"))

> summary(model1)

> cbind(exp(coef(model1)),exp(confint(model1)))

> cbind(exp(coef(model1)),exp(confint.default(model1)))
```



# Test for trend

## Slide 55-56

Modellen antager linearitet i skostørrelse:  $p_i = \alpha - \beta \times \text{sko}_i$

```
skonummer = c(rep(3.5,22),rep(4,35),rep(4.5,42),rep(5,48),
              rep(5.5,54),rep(6,150))
snit = c(rep("ja",5),rep("nej",17),rep("ja",7),rep("nej",28),
         rep("ja",6),rep("nej",36),rep("ja",7),rep("nej",41),
         rep("ja",8),rep("nej",46),rep("ja",10),rep("nej",140))

> table(skonummer,snit)
      snit
skonummer   ja nej
  3.5     5 17
  4       7 28
  4.5    6 36
  5       7 41
  5.5    8 46
  6     10 140

kejsersnit=(snit=="ja")
model2 = glm(kejsersnit ~skonummer, family=binomial(link="identity"))
```



# Modelkontrol af lineariteten, kejsersnit

Slide 57-58

**Trick** (i alle former for regression):

Når kovariaten kun antager så få værdier, kan linearitetsantagelsen checkes ved at sætte en kopi af skonummer ind som faktor oveni, og så teste, om denne kan undværes:

```
model3 = glm(kejsersnit ~ skonummer + factor(skonummer),  
             family=binomial(link="identity"))  
anova(model3,test="LR")
```

Modellen ville være den samme, hvis skonummer blev udeladt, men så ville vi ikke få testet, om modellen med **kun skonummer** var fornuftig



# Proportional odds model

Slide 66-67

*Logistisk regression* for hver tærskel,  
med **samme afhængighed** af kovariaterne,  
som her alle er  $\log_2$ -transformerede:

```
library(MASS)  
  
m <- polr(fibrosegrad ~ lha + lpiiinp + lykl40, data = fib, Hess=TRUE)
```

Odds ratio vil **ikke afhænge af cutpoint**,

```
> summary(m)  
  
> ctable=coef(summary(m))  
> p <- pnorm(abs(ctable[, "t value"]), lower.tail = FALSE) * 2  
> ptable <- cbind(ctable, "p value" = p)  
  
> ptable[1:3,]  
  
> cbind(exp(coef(m)),exp(confint(m)))
```



# Poisson analyse, med interaktion

Slide 82-83

Testvenlig kode:

```
model1 = glm(antal ~ gender + years.from2004  
            + gender:years.from2004,  
family=poisson(link="log"),data=total)  
summary(model1)  
anova(model1,test="LR")  
cbind(exp(coef(model2)),exp(confint(model2)))[3:4,]
```

Estimationsvenlig kode:

```
model2 = glm(antal ~ gender + gender:years.from2004,  
family=poisson(link="log"),data=total)  
summary(model2)  
cbind(exp(coef(model2)),exp(confint(model2)))
```



# Poisson analyse

Slide 85-86

Her bruges family=quasipoisson for at korrigere for overspredning,  
ellers helt som s. 111

```
model3.quasi = glm(antal ~ gender + years.from2004,  
family=quasipoisson(link="log"),data=total)  
  
summary(model3.quasi)  
  
cbind(exp(coef(model3.quasi)),exp(confint(model3.quasi)))[2:3,]
```



# Normalfordelingsmodel for tælletal

## Slide 87

foretages på logaritmetransformerede data:

```
total$logantal=log(total$antal):
```

```
model3.nf = lm(logantal ~ gender + years.from2004, data=total)
summary(model3.nf)
cbind(exp(coef(model3.nf)),exp(confint(model3.nf)))[2:3,]
```



# Poisson analyse, kun for 18-24 årige

Slide 91-92

```
trafik18.24 <- subset(trafik, age=="18-24-ye")  
  
m1.quasi = glm(antal ~ gender + years.from2004 + gender:years.from2004,  
               family=quasipoisson(link="log"), data=trafik18.24)  
summary(m1.quasi)  
  
m2.quasi = glm(antal ~ gender + gender:years.from2004,  
               family=quasipoisson(link="log"), data=trafik18.24)  
  
cbind(exp(coef(m2.quasi)), exp(confint(m2.quasi)))[3:4,]
```

